

Primljen / Received: 21.12.2018.

Ispravljen / Corrected: 2.5.2019.

Prihvaćen / Accepted: 1.7.2019.

Dostupno online / Available online: 23.9.2019.

Mogućnosti primjene ekspertnih metoda za optimizaciju održavanja sustava odvodnje

Pregledni rad

[Dino Obradović, Marija Šperac, Saša Marenjak](#)

Mogućnosti primjene ekspertnih metoda za optimizaciju održavanja sustava odvodnje

U radu je dan pregled dosadašnjih istraživanja o mogućnostima primjene ekspertnih metoda (umjetne neuronske mreže, genetski algoritmi, ekspertni sustavi, stabla odlučivanja, Markovljevi lanci i algoritam kolonije mrava) za optimizaciju održavanja sustava odvodnje. Pravodobno održavanje sustava odvodnje važno je zbog njegova pravilnog funkcioniranja, manjih troškova popravaka i osiguranja osnovne funkcije sustava odvodnje, te odvođenja otpadne vode iz kućanstava do uređaja za pročišćavanje otpadnih voda i ispuštanja u prijamnik. Navedene su moguće primjene ekspertnih metoda u optimizaciji održavanja sustava odvodnje čiji je cilj smanjiti troškove održavanja.

Ključne riječi:

ekspertni sustavi, sustav odvodnje, održavanje, optimizacija, umjetna inteligencija

Subject review

[Dino Obradović, Marija Šperac, Saša Marenjak](#)

Possibilities of using expert methods for sewer system maintenance optimisation

This paper provides an overview of the state-of-the-art research on the possibilities of using expert methods (artificial neural networks, genetic algorithms, expert systems, decision trees, Markov chains, and ant colony algorithm) for optimising maintenance of sewerage systems. Timely maintenance of sewerage systems is significant as it ensures their proper functioning, repair cost reductions, basic operation of the system, drainage of waste water from households to wastewater treatment plants, and discharge to the receiving water body. Possible uses of expert methods for optimising maintenance of sewerage systems, aimed at reducing maintenance costs, are presented.

Key words:

expert systems, sewerage system, maintenance, optimisation, artificial intelligence

Übersichtsarbeit

[Dino Obradović, Marija Šperac, Saša Marenjak](#)

Möglichkeiten der Anwendung fachkundiger Methoden zur Optimierung der Wartung von Abwassersystemen

In dieser Arbeit werden bisherige Forschungsergebnisse zu den Möglichkeiten des Einsatzes von fachkundigen Methoden (künstliche neuronale Netze, genetische Algorithmen, Expertensysteme, Entscheidungsbäume, Markov-Ketten und Ameisenkolonie-Algorithmus) zur Optimierung der Wartung von Abwassersystemen vorgestellt. Die rechtzeitige Wartung des Abwassersystems ist wichtig, da es ordnungsgemäß funktioniert, die Reparaturkosten senkt und die Grundfunktionen des Abwassersystems sicherstellt sowie das Abwasser aus Haushalten in die Kläranlage leitet und in den Auffangbehälter ablässt. Es werden mögliche Anwendungen von fachkundigen Methoden zur Optimierung der Wartung von Abwassersystemen mit dem Ziel, die Wartungskosten zu senken, aufgeführt.

Schlüsselwörter:

Expertensysteme, Abwassersystem, Wartung, Optimierung, künstliche Intelligenz



Dino Obradović, mag.ing.aedif.

Sveučilište J. J. Strossmayera u Osijeku
Građevinski i arhitektonski fakultet Osijek
dobradovic@gfos.hr



Izv.prof.dr.sc. Marija Šperac, dipl.ing.građ.

Sveučilište J. J. Strossmayera u Osijeku
Građevinski i arhitektonski fakultet Osijek
msperac@gfos.hr



Prof.dr.sc. Saša Marenjak, dipl.ing.građ.

Sveučilište J. J. Strossmayera u Osijeku
Građevinski i arhitektonski fakultet Osijek
sasa@marenjak.com

1. Uvod

Kanalizacijskim sustavom smatra se skup građevina i naprava pomoću kojih se otpadne vode skupljaju, odvođe, čiste i ispuštaju u odgovarajući prijamnik [1, 2]. Osnovni je zadatak sustava odvodnje da se zagađene vode što brže odstrane iz ljudske blizine, uz što povoljnije sanitarne, tehničke, tehnološke i ekonomske uvjete. Osim toga, zadatak je sustava odvodnje i to da sve prikupljene vode pročiste do potrebnog stupnja i ispuste iste u prijamnike, a sve u skladu s ekološkim zahtjevima, pravilima struke i zakonskim propisima [3, 4]. Kako bi sustav odvodnje ispunjavao sve svoje zadatke, važno je njegovo adekvatno održavanje.

Dobro i pravilno održavanje sustava odvodnje osnovni je preduvjet za racionalno gospodarenje ovom skupom gradskom infrastrukturom, za adekvatne sanitarne uvjete u urbanoj sredini i za dobru zaštitu okoliša. Također, to je jedan od preduvjeta za održivi razvoj i zdravstveni standard urbane sredine, stoga mu se mora usmjeriti velika pozornost [5-8]. Pod pojmom dobro i pravilno održavanje smatra se odgovarajući način, odnosno strategija održavanja koja predviđa moguće nedostatke i kvarove (težište je na preventivnom održavanju), te je ekonomski učinkovita.

Održavanje uključuje skup različitih aktivnosti i postupaka koji se izvode kako bi građevina ili bilo koji njezin dio zadržao svoju prvobitnu namjenu i kako bi se svim korisnicima te građevine moglo jamčiti sigurno korištenje te kako bi građevina što dulje bila u ispravnom stanju i mogla zadovoljavati svoju namjenu [9-12]. Kada je pravilno održavan, sustav odvodnje odvodi otpadnu vodu iz kuća i zgrada na uređaj za pročišćavanje te na taj način štiti zdravlje čovjeka [7, 8].

Postoji više strategija održavanja, a dvije najvažnije su preventivno i korektivno održavanje [11, 13] koje će pobliže biti objašnjene u drugom poglavlju ovog rada. Jedan od najvažnijih preduvjeta za jednostavno i ekonomski opravdano održavanje te dostizanje projektiranog životnog vijeka jest pravilno provedeno projektiranje sustava odvodnje. Kod projektiranja sustava odvodnje, projektanti se susreću s mnogo pitanja, problema i odluka, jer treba zadovoljiti mnoge kriterije. Neki od kriterija koje treba ostvariti da sustav odvodnje ispravno funkcionira jesu: dovoljan promjer cijevi za odvođenje određene količine otpadne vode, osiguranje ograničenja brzine u cijevima, osiguranje pravilne ispunjenosti poprečnog profila cijevi, određivanje uzdužnih padova cijevi koji omogućuju najbolju odvodnju, itd., ali uz uvjet da je izvedba ekonomski učinkovita. Općenito gledajući, višekriterijsko odlučivanje je složeno te pomaže u donošenju konačne odluke kada se razmatra veći broj varijantnih rješenja. Višekriterijsko odlučivanje definira se u trećem poglavlju te se donosi pregled ekspertnih metoda koje mogu pomoći pri optimizaciji održavanja sustava odvodnje.

2. Održavanje sustava odvodnje

Kako je već spomenuto, održavanje se, između ostaloga, izvodi kako bi građevina zadovoljila svoju namjenu, što u slučaju

sustava odvodnje znači odvođenje otpadne vode na uređaj za pročišćavanje uz zadovoljenje svih potrebnih uvjeta.

Proaktivno i preventivno održavanje kanalizacijskih sustava troškovno je povoljnije nego tradicionalni pristup održavanju, tj. reaktivno održavanje [14]. Već tijekom projektiranja sustava odvodnje mora se misliti na mogućnosti održavanja, a upravo održavanje uvjetuje (naravno, ne u cijelosti) potrebne minimalne promjere cijevi. Na početku dionica količine kanalizacijskih voda često su vrlo male, posebno za odvodnju sanitarnih otpadnih voda u razdjelnom sustavu. Teoretski bi bilo moguće upotrebljavati vrlo male poprečne profile cijevi na osnovi malih početnih protoka i uzdužnih nagiba, ali je iskustvo pokazalo da je primjena malih poprečnih profila nepovoljna te da često dolazi do začepjenja cijevi. Primjenom malih poprečnih profila cijevi u kanalizacijskom sustavu znatno se povećavaju troškovi održavanja gravitacijskog sustava odvodnje, a sve zbog potrebe čestog čišćenja. Zbog svega toga, u javnim je kanalizacijskim sustavima s gravitacijskim pogonom otpadnih voda uobičajena primjena najmanjih poprečnih profila od 250 do 300 mm [15].

Unutar sustava odvodnje odvija se cijeli niz procesa: biološki, fizikalni i kemijski koji svojom aktivnošću ugrožavaju funkcioniranje sustava odvodnje. Biološki procesi rezultiraju obraštanjem i procesima razgradnje, kemijski stvaranjem kiselina koje nagrizaju dijelove sustava odvodnje, a kao tipični fizikalni proces javlja se taloženje [16]. Ako je sustav odvodnje dobro projektiran i građevinski izveden (prema pravilima struke i prema svim propisima), onda se održavanje svodi na povremeno čišćenje od taloga - mulja, pijeska, uz naravno, redovite preglede [17]. Čišćenje se može obavljati mehaničkim sredstvima ili ispiranjem, ovisno o količini taloga, pojavi korijenja drveća u cijevima [18, 19], začepljenju koje uzrokuju korisnici bacanjem otpadaka, itd.

Neki od uvjeta za dobro održavanje sustava odvodnje podrazumijevaju dobro poznavanje sustava i njegove značajke, dovoljan broj dobro organiziranih zaposlenika, dostatne financijske resurse [3, 15] te kontrolu i nadzor svih postupaka održavanja koji se provode [20]. Svi ti uvjeti su međusobno povezani. Bez dostatnih financijskih sredstava, broj zaposlenika neće biti dovoljan za održavanje sustava. Bez dobre organizacije i plana održavanja, zaposlenici ne mogu učinkovito održavati sustav, iako ih ima dovoljno. Čak i ako su ti uvjeti zadovoljeni, bez dobrog poznavanja sustava ne može se računati na pouzdanu razinu održavanja sustava odvodnje. Budući da je svaki sustav odvodnje jedinstven, pretpostavlja se da će i pristup njegovom upravljanju i održavanju biti jedinstven. Svaki dio sustava odvodnje zahtijeva prikladan plan upravljanja i održavanja [3, 5]. Održavanje može biti korektivno i preventivno [11, 12]. Korektivno održavanje je reaktivni tip održavanja koji je najčešće potreban u slučajevima kada oprema ili sustav otkazu ili su potrošeni. Sustavi koji se oslanjaju samo na taj tip održavanja radit će manje povoljno, pogotovo u starijoj fazi. Korektivno održavanje naziva se također održavanje u nuždi, ali se pritom razlikuju tzv. normalna situacija i izvanredna situacija. Normalna situacija podrazumijeva da su trenutačno začepljene cijevi ili se pojavila

pukotina. Učinkovitim programom održavanja učestalost takvih pojava se smanjuje. Izvanredne situacije odnose se najčešće na oluje, poplave, potrese ili neke druge nepredvidive događaje koji dovode do prekida rada dijela ili cijelog sustava. Potpuno oslanjanje na korektivno održavanje dovodi do nemogućnosti planiranja i raspoređivanja radnih zadataka, do nemogućnosti dovoljnog i adekvatnog dodjeljivanja sredstava u proračun te do učestalih kvarova opreme i sustava. Preventivno održavanje je proaktivni tip održavanja, te predstavlja programirano i planirano održavanje usmjereno na sprječavanje smetnji i kvarova. Može se rasporediti prema povijesnim potrebama sustava ili prema određenim vremenskim razmacima. Preventivno održavanje dovodi do poboljšanog rada sustava, osim u slučajevima kada su poteškoće u sustavu posljedica greške u projektu ili izvedbi. Budući da se aktivnosti održavanja mogu planirati i smjestiti u raspored, resursi potrebni za održavanje mogu se na vrijeme nabaviti i planirati u proračunu [5].

Sustav odvodnje vrlo je dugačak i razgranat, sastoji se od mnogo dijelova, pa je teško predvidjeti sve moguće probleme (pogotovo u početku njegova rada). Zato su potrebni redoviti pregledi i pritom usredotočenost na one dijelove koji mogu biti problematični. Naime, nasumično pregledavanje sustava odvodnje da bi se procijenilo stanje je skupo, stoga je neprihvatljivo [21]. Iz svega se može zaključiti da je održavanje sustava odvodnje vrlo složen zadatak [22, 23], pa se učinkovitim rasporedom preventivnog održavanja u mnogome smanjuju ukupni troškovi održavanja [24], pri čemu mogu uvelike pomoći ekspertne metode.

3. Ekspertne metode za optimizaciju održavanja sustava odvodnje

Višekriterijsko odlučivanje, koje se primjenjuje i kod održavanja sustava odvodnje, odnosi se na situacije odlučivanja kada

postoji veći broj, najčešće, konfliktnih kriterija [25, 26]. Kod takvih problema veliko značenje ima optimizacija. Zadatak je optimizacije izabrati najbolju varijantu (najboljeg rješenja) iz niza mogućih varijanti, ili iz niza povoljnih, u smislu usvojenog kriterija.

Optimizacija u matematičkom smislu se uvijek svodi na traženje ekstrema kriterijske funkcije (jedne funkcije ili vektora više funkcija). Optimizacija se radi primjenom različitih metoda, ovisno o tipu relacije u matematičkom modelu, kriterijskoj funkciji i ograničenju [27]. Matematički modeli se sastoje od varijabli, koeficijenata i matematičkih operatora. Matematičko modeliranje ne mora nužno riješiti problem, ali će vjerojatno rasvijetliti problem i razjasniti promatranu situaciju [28]. Modeliranje i rješavanje modela gotovo se uvijek izvodi pomoću računala i odgovarajućeg programa [27].

Optimizacijskim metodama se može riješiti širok spektar inženjerskih problema [29], a jedan od njih je i optimizacija održavanja sustava odvodnje. Općenito, cilj optimizacije može biti smanjenje potrošnje energije i troškova, maksimizacija zarade, minimizacija rizika [30], itd., a sve to može se primijeniti kod održavanja sustava odvodnje. Većina tehničkih sustava u suvremenom inženjerstvu može se projektirati i ostvariti na različite načine ovisno o volji projektanta. S tim u vezi, postavlja se pitanje pronalaženja određenih karakteristika da bi sustav, u određenom smislu, bio optimalan. Pojam optimalnosti je relativan i strogo ovisi o kriteriju optimalnosti. Optimizacija je postupak čiji je cilj dobiti najbolje rezultate pri određenim uvjetima. Da bi se zadatak optimizacije pravilno postavio, nužno je točno identificirati predmet optimizacije, kao i cilj ili kriterij optimizacije [31]. Umjetna inteligencija, prema povijesnoj definiciji je znanje izrade strojeva koji su sposobni za obavljanje aktivnosti koje zahtijevaju ljudsku inteligenciju [32, 33].

Jedno od područja kojima se umjetna inteligencija bavi jesu i ekspertni sustavi. Ekspertni sustavi primjenjuju se kako bi se,


Tablica 1. Kronološki popis ekspertnih metoda s osnovnim karakteristikama i područjem primjene u optimizaciji održavanja sustava odvodnje

Ekspertna metoda	Autori metode	Godina	Izvor	Područje primjene
Markovljevi lanci	Markov	1913.	[34]	Procjena stanja starosti cijevi sustava odvodnje [35-44]
Umjetne neuronske mreže	McCulloch i Pitts	1943.	[45]	Predviđanje stanja sustava odvodnje [46] Predviđanje trajanja sustava odvodnje [47] Detekcija oštećenja cijevi [48-52]
Stabla odlučivanja	Belson	1959.	[53]	Planiranje pregleda kanalizacijskih cijevi [54] Predviđanje začepjenja sustava odvodnje [55]
Ekspertni sustavi	Buchanan, Feigenbaum i Lederberg	1968.	[56]	Odlučivanje o prioritetima kod obnove sustava odvodnje [57] Određivanje prioriteta pregleda sustava [58, 59] Predviđanje kritičnih dijelova sustava [60] Potpora odlučivanju tijekom uporabe i održavanja sustava odvodnje [61-63]
Genetski algoritmi	Holland	1975.	[64]	Odlučivanje za optimalni način obnove sustava [65-68] Pomoć tijekom pregleda kanalizacijskih cijevi, određivanje rizika od oštećenja cijevi, troškova pregleda i troškova popravaka [69]
Optimizacija kolonijom mrava	Colorni, Dorigo i Maniezzo	1991.	[70]	Optimizacija planiranja pregleda infrastrukturnih građevina [71]

između ostaloga, projektantu olakšalo donošenje odluka, odnosno olakšala i ubrzala optimizacija održavanja za koju su zaduženi zaposlenici u komunalnom poduzeću koje upravlja kanalizacijskim sustavom. U tablici 1., se uz svaku ekspertnu metodu kronološki navode njeni autori te godina nastanka metode, izvor te područje njezine primjene u optimizaciji održavanja sustava odvodnje i pripadajući literaturni izvori. Važno je naglasiti da je godina nastanka neke od metoda relativno nejasna te se ne može točno odrediti jer autorima dostupna literatura daje proturječna vremena nastanka (iako odstupanja iznose do tri godine). Stoga su u tablici 1. navedena vremena nastanka prema onoj literaturi koja se smatra vjerodostojnijom te se odlučilo za onu godinu nastanka koja se više spominje u relevantnoj literaturi.

3.1. Markovljevi lanci

Markovljevi lanci (po Andreju Andrejeviču Markovu) [72] (eng. *Markov chains*) jedan su od najjednostavnijih modela slučajne evolucije. Jednostavna struktura Markovljevih lanaca omogućuje nam veliku količinu znanja o njihovu ponašanju, a ujedno, klasa Markovljevih lanaca je dosta široka za upotrebu u raznim aplikacijama. Markovljevi lanci se danas upotrebljavaju u statistici, biologiji, pa čak i u književnosti. To čini Markovljeve lance najvažnijim primjerom slučajnih procesa [72]. Markovljev lanac se opisuje dijagramima stanja koji se sastoje od stanja (kružići) i dopuštenih tranzicija između njih (linije sa strelicama) (slika 1.) [73].



Slika 1. Dijagram prijelaznih vrijednosti Markovljevog lanca [74]

Kod lanaca kontinuiranih u vremenu tranzicija se može javiti u bilo kojem trenutku i opisati parametrom eksponencijalne raspodjele [72]. Markovljevi lanci predstavljaju niz stanja sustava. U svakome trenutku sustav može prijeći u neko novo stanje ili može ostati u istome stanju. Promjene stanja nazivaju se tranzicije. Ako slijed stanja ima Markovljevo svojstvo, to znači da je svako buduće stanje vremenski neovisno o svakome prijašnjem stanju.

Autori Ana i Bauwens [35] modeliraju proces starenja - propadanja cijevi gradske oborinske odvodnje pomoću Markovljevog lanca. Markovljev model je moćan algoritam za modeliranje starenja kanalizacijskih cijevi, jer ne samo što je njegov koncept jednostavan, nego i njegova struktura dopušta složene i nasljedne događaje poput starenja cijevi.

Wirahadikusumah, Abraham i Castello [36] primjenjuju Markovljev proces odlučivanja pri obnovi sustava odvodnje. Razumijevanje mehanizama starenja sustava odvodnje omogućuje stručnjacima zaduženima za njegovo održavanje i kontrolu razvijati model za procjenu hoće li se dogoditi kvar sustava odvodnje ili neće. Upotreba modela starenja zajedno s analizom troškova životnog ciklusa (eng. *life cycle cost analysis*, LCCA) omogućuje smanjenje troškova građenja, upravljanja i održavanja. Marzouk i Omar [37] rade algoritam za višekriterijsku optimizaciju obnove kanalizacijske mreže. Model koristi Markovljev lanac za predviđanje starenja sustava odvodnje. Markovljevi modeli daju pouzdan mehanizam za razvoj prediktivnih modela. Matrica prijelaza je kvadratnog oblika. Modul za predviđanje stanja sustava odvodnje predviđa stanje za idućih 50 godina.

Autori Micevski i sur. [38] napravili su Markovljev model za starenje cijevi oborinske odvodnje. Model je kalibriran pomoću Bayesove metode i podataka o strukturi iz baze podataka grada Newcastla (Australija). Markovljeve prijelazne vjerojatnosti su procijenjene uz pomoć Metropolis-Hastingsovog algoritma. Pokazano je da je Markovljev model prikladan za modeliranje starenja cijevi. Utvrđeno je da različite karakteristike cijevi utječu na proces starenja, kao što su: promjer cijevi, materijal, vrsta tla i stupanj izloženosti u smislu udaljenosti cijevi od obale. Baik, Abraham i Gipson [39] koriste Markovljev lanac u modelu starenja koji je razvijen pomoću podataka o kanalizacijskom sustavu grada San Diegoa.

U radu grupe autora [40] govori se o analizi troškova životnog ciklusa upravljanja podzemnom infrastrukturom temeljenoj na optimalnom održavanju i obnovi. Markovljev lanac (i pripadajući model starenja) pomaže objasniti starenje cijevi tijekom godina. Modeli Markovljevih lanaca već su prije uspješno primjenjivani za predviđanje starenja različite infrastrukture. Dobivena krivulja starenja sustava odvodnje nije linearna nego eksponencijalna, što znači da sustav odvodnje ne stari jednako u vremenu.

Baik, Jeong i Abraham [41] razvili su modele starenja u upravljanju kanalizacijskim sustavima na osnovi Markovljevog lanca. Utvrđeno je da su neki od potrebnih podataka za uspješnije i točnije predviđanje starenja kanalizacijskih sustava dubina postavljanja cijevi, vrsta (stanje) tla, razina podzemne vode, učestalost prelijevanja sustava odvodnje, itd.

Autori Lubini i Fuamba [42] razvili su probabilistički model osmišljen za istraživanje stanja kanalizacijskih cijevi ovisno o uvjetima rada i uvjetima održavanja. Tvrdi da model Markovljevih lanaca najviše služi za predviđanje pogoršanja stanja (starenja) infrastrukturnih sustava, a osobito mostova i kanalizacijskih sustava. Zaključili su da su potrebni dodatni parametri kao što su alkalnost, koncentracija organskih tvari i metala, itd., kako bi model bio pouzdaniji i točniji te veća baza podataka.

Wirahadikusumah, Abraham i Iseley [43] tvrde da postoje dva glavna razloga zašto je način održavanja sustava odvodnje reaktivan. Naime, sustav odvodnje smješten je pod zemljom pa se njegovo stanje ne može lako utvrditi i vidjeti sve dok se ne pojavi neki kvar ili problem u funkcioniranju. Osim toga, kanalizacijskim sustavima upravljaju jedinice lokalne samouprave (odnosno različita komunalna poduzeća) te ne postoje univerzalni načini i propisi za održavanje. Spomenuti autori primjenjuju Markovljeve lance u kombinaciji s nelinearnom optimizacijom kako bi razvili model starenja sustava odvodnje. Model starenja sustava se treba temeljiti, između ostalog, na velikoj povijesnoj bazi podataka. Ostali važni podatci koji utječu na starenje sustava su: vrsta materijala od kojeg su cijevi napravljene, razina podzemne vode, vrsta nasutog tla iznad cijevi i visina nadsloja tla.

Jin i Mukherjee [44] razvili su stohastički model koji se može primijeniti prilikom karakterizacije i predviđanja slučajnih kvarova u infrastrukturnom sustavu. Posebno su se usmjerili na začepjenja u kanalizacijskom sustavu koja su rezultat kombinacije raznih faktora, uključujući starenje, tj. pogoršanje stanja. Korišteni su podatci o kanalizacijskom sustavu kojima raspolaže mala općina. Zaključuju da je model primjenjiv na sustav odvodnje, ali i na ostale infrastrukturne sustave pri predviđanju slučajnih kvarova.

3.2. Umjetne neuronske mreže

Jedna od preciznijih i jednostavnijih definicija umjetnih neuronskih mreža (eng. *Artificial neural networks - ANN*) jest ona iz 1990. godine koju su dali Aleksander i Morton. Oni definiraju neuronsku mrežu kao "masivni paralelni distribuirani sustav za obradu podataka koji se sastoji od jednostavnih elemenata i ima prirodnu sklonost pohranjivanja iskustvenog znanja koje potom može i koristiti, a sličan je mozgu prema načinu na koji stječe i pohranjuje znanje" [75, 76]. Neuronska mreža znanje stječe kroz proces učenja, a pohranjuje ga posredstvom intenziteta međuneuronskih mreža [75, 76]. Proučavanje neuronskih mreža je započelo s publikacijom koju su napisali McCulloch i Pitts [77]. Svaka neuronska mreža sastoji se od većeg broja strukturnih procesnih jedinica - neurona [78-81]. Neuroni su međusobno povezani vezama koje sadrže propusne (težinske) koeficijente, a po funkciji su slični sinapsama kod bioloških neurona [78].

Najafi i Kulandaivel [46] razvili su model temeljen na umjetnoj neuronskoj mreži koji predviđa stanje kanalizacijskih cijevi na osnovi povijesnih podataka o procjeni stanja sustava. Podatci koji su korišteni pri modeliranju neuronske mreže jesu: duljina cijevi, promjer cijevi, vrsta materijala, starost kanalizacijskih cijevi, dubina postavljanja cijevi, nagib i vrsta sustava odvodnje. Zaključili su da je primjena umjetnih neuronskih mreža za predviđanje stanja sustava odvodnje izvediva, a točnost modela ovisi o veličini promatranog uzorka i količini korištenih podataka. U radu autora Jianga i sur. [47] razvijena je umjetna neuronska mreža za predviđanje trajanja betonskih cijevi kanalizacijske mreže temeljena na modeliranju stupnja korozije. ANN je trenirana i validirana s eksperimentalno dobivenim podacima

(4,5 godine je trajao eksperiment, korištene su laboratorijske komore za koroziju), a verifikacija je rađena pomoću stvarnih podataka dobivenih diljem australske kanalizacijske mreže. Dobivena su dosta dobra predviđanja korozije cijevi te je zaključeno da se ANN može rabiti za poboljšanje razumijevanja mehanizama korozije.

Rad autora Moselhija i Shehab-Eldeena [48] bavi se automatskom detekcijom površinskih oštećenja cijevi. Proces snimanja kanalizacijskih cijevi, pregledavanja snimki te na kraju, najvažnijeg dijela - otkrivanja površinskih oštećenja, obično zahtijeva mnogo vremena, naporan je i skup. Osim toga, može se pogriješiti zbog gubitka koncentracije onih koji to rade. Automatizacija u tom području uključuje računalno snimanje, digitalne videosnimke, obradu snimaka i njihovu analizu, prepoznavanje uzoraka i klasifikaciju pomoću ANN-a. Umjetna neuronska mreža je trenirana kako bi prepoznala oštećenja cijevi, a program koji je rađen je *NeuroShell 2*. Nakon treniranja mreže uočeno je da je ANN pogodna za otkrivanje oštećenja na betonskim i glinenim cijevima.

Sinha i Fieguth [49] koriste ANN kako bi prepoznali oštećenja cijevi pod zemljom, kao što su slučajno oblikovane pukotine i rupe, slomljene spojnice i bočni priključci te ostalo. U ovom radu umjetna neuronska mreža služi kako bi se klasificirali i prepoznali uzorci navedenih oštećenja. Umjetna neuronska mreža se trenira, ali se mora paziti da se u tome ne pretjera jer bi rezultati mogli biti lošiji (netočniji) nego prije treniranja mreže [49].

Autori Tran, Perera i Ng [50, 51] bave se sličnom problematikom. Obrađuju problem pogoršanja strukture kanalizacijskih cijevi, i to samo onih za oborinsku odvodnju u Australiji. Snimanja su obično rađena pomoću kamera (eng. *closed-circuit television, CCTV*) te se na osnovi tako dobivenih snimaka radila procjena stanja cijevi. Autori predlažu model utemeljen na umjetnim neuronskim mrežama koji bi procjenjivao stanje betonskih kanalizacijskih cijevi pomoću određenih zadanih podataka (ulaznih faktora).

Odabrane su betonske cijevi zato što je od njih sastavljena većina takvog sustava odvodnje. Program koji je rađen za izradu ANN je MATLAB.

Jedan od problema koji se javlja pri održavanju sustava odvodnje je pronos i taloženje sedimenta. Talozjenje se uobičajeno javlja zbog promjene protoka kroz cijevi. Ebtehaj i Bonakdari [52] koriste ANN kako bi predvidjeli pronos sedimenta u kanalizacijskim cijevima. Predvidjeti količinu sedimenta važno je zato što mogućnost točnog predviđanja količine sedimenta i mjesta taloženja smanjuje troškove održavanja sustava odvodnje. Zaključili su da je predviđanje taloženja sedimenta pomoću ANN veoma blizu stvarnim mjerenjima.

3.3. Stabla odlučivanja

Stablo odlučivanja (eng. *decision tree*) naziv je za stablasto strukturirani dijagram koji može prikazivati sva moguća rješenja nekog problema, sve moguće ishode nekog događaja

ili pak klasificirati određene podatke [82, 83]. Svaka grana stabla odlučivanja se obično može prikazati kao jedno AKO-ONDA (eng. *IF-THEN*) pravilo [82]. Iako je struktura slična, bitno je razlikovati dvije potpuno različite domene primjene stabla odlučivanja: stablo odlučivanja u strojnom učenju i stablo odlučivanja u teoriji odlučivanja [82, 84]. Kod stabla odlučivanja postoje dvije vrste čvorova:

- **čvor odluke:** definira određeni kriterij u obliku vrijednosti atributa iz kojeg izlaze grane koje zadovoljavaju određene vrijednosti tog atributa [85],
- **krajnji čvor:** njime završava određena grana stabla [84]; krajnji čvorovi definiraju klasu kojoj pripadaju primjeri koji zadovoljavaju uvjete na toj grani stabla [85].

Autori Harvey i McBean [54] koriste stablo odlučivanja tijekom planiranja pregleda kanalizacijskih cijevi. Poznato je da je predviđanje stanja cijevi posebno težak zadatak, a primjenom stabla odlučivanja uvelike se olakšava zadatak odabira cijevi koje će se pregledavati. Sam koncept stabla odlučivanja je općenit i dobiveni model razumljiv je i onima koji nisu upoznati s metodama rudarenja podataka i znanjem koje često nedostaje kada se primjenjuju statističke metode ili metode strojnog učenja. Atributi koji su korišteni za rudarenje podataka su: materijal, starost, vrsta (glavni ili priključni cjevovod), promjer, dužina, nagib, dubina dna cijevi, dubina, vrsta pokrova na terenu iznad cijevi, puknuća vodovodnih cijevi unutar tri metra od cijevi, stanje cijevi. Zaključeno je da su stabla odlučivanja jednostavna i učinkovita metoda koja daje dubok uvid kako određeni parametri cijevi utječu na strukturno stanje pojedinačnih cijevi. Trenirani klasifikator stabla odlučivanja ukazuje da je starost cijevi važna za određivanje strukturnog stanja sanitarnog sustava odvodnje. Također, stablo odlučivanja pokazuje da postoji povećana mogućnost kvara cijevi u slučaju kada je cijev postavljena pliće, kada je veće duljine, manjeg promjera i kada je u blizini takve cijevi bilo puknuće vodovodne cijevi.

Proaktivno održavanje je važno kako bi se smanjila učestalost začepjenja sustava odvodnje, smanjili troškovi, nepovoljan utjecaj na ljude i okoliš. Za učinkovito određivanje prioriteta održavanja bitan je točan model predviđanja kvarova/problema sustava odvodnje. Bailey i sur. [55] razvili su takav model temeljen na stablu odlučivanja koji koristi povijesne podatke o problemima (incidentima) i održavanju sustava odvodnje. Rezultati su pokazali ograničene mogućnosti određivanja prioriteta održavanja.

3.4. Ekspertni sustavi

Ekspertni sustavi (eng. *Expert systems* - ES) programi su, metode za sistematiziranu upotrebu znanja u nekom specifičnom području [86, 87]. Oni predstavljaju oblik umjetne inteligencije [32, 88, 89] i često se upotrebljavaju tijekom donošenja odluka o složenim problemima [88, 90]. Klasični ekspertni sustavi slijede postupak logičke dedukcije koji se odvija u koracima (ciklusima) obuhvaćajući početno, ciljano te cijeli niz trenutačnih

stanja. Odluka se donosi uspoređivanjem trenutačnih stanja s općim, uzročno-posljedičnim odnosima pohranjenima u bazi znanja. Postupak zaključivanja može slijediti obrazac ulančavanja unaprijed ili unatrag. Polazeći od početnoga stanja, ulančavanjem unaprijed u koracima se kroz dijalog s korisnikom sužava skup mogućih rješenja, sve do ciljanog stanja. Dvojbene situacije rješavaju se uz primjenu pravila iz baze znanja s višim oznakama izvjesnosti [91]. Ekspertni sustavi rješavaju probleme koji se općenito mogu svrstati u neku od sljedećih kategorija: interpretacija, predviđanje, dijagnoza, oblikovanje, planiranje, nadgledanje, popravak, odabir i kontrola [92, 93].

Tagherout, Bennis i Bengassem [57] razvili su ekspertni sustav kako bi pomogao pri odlučivanju o tome koji su prioriteti za obnovu kanalizacijske mreže. Doprinos je u tome što je razvijen sustav vrednovanja prioriteta za obnovu sustava odvodnje. Za svaki dio kanalizacijske mreže izračunan je indeks svojstava, posebno za strukturna, hidraulična i globalna svojstva, uzimajući u obzir stanje unutar cijevi, hidraulična svojstva cijevi te okruženje promatrane cijevi. Cijevi s istim hidrauličnim i strukturalnim svojstvima klasificirane su različito kada su imale različit stupanj osjetljivosti s obzirom na položaj. Ta klasifikacija, koja je preciznija, daje određene prednosti pri odlučivanju o tome koje će se cijevi obnoviti. Također, prednost ovog načina vrednovanja nije samo to što u obzir uzima više različitih parametara, nego što razmatra i njihovo međudjelovanje.

Hahn, Palmer i Merrill [58] razvili su ES koji služi za određivanje prioriteta pregleda sustava odvodnje. Ekspertni sustav određuje potencijalni rizik i moguće posljedice, predlaže prikladnu metodu pregleda i upozorava korisnika kada je potrebno više (dodatnih) informacija kako bi se postiglo preciznije odlučivanje. U modulu za zaključivanje (eng. *Inference engine*), jednom od sastavnih dijelova ekspertnog sustava [94, 95], upotrijebljena je Bayesova mreža.

U radu [59] razvijen je ES i pripadajuća baza podataka za pomoć odlučivanja tijekom pregleda sustava odvodnje. Ekspertni sustav je rađen pomoću Bayesove mreže koja dopušta nesigurnost znanja stručnjaka kroz cijeli proces odlučivanja. Bazu podataka i ekspertne sustave ocjenjivalo se pomoću nekoliko studija slučaja te se pokazalo da su djelotvorni kod oponašanja znanja stručnjaka. Baza ekspertnog sustava poznatog kao SCRAPS (od eng. *Sewer Cataloging, Retrieval and Prioritization System*, SCRAPS, tj. "sustav za katalogizaciju kanalizacije, davanje podataka i prioritizaciju") jest Bayesova mreža. Također, kako sustav odvodnje stari tako su potrebni sve skuplji pregledi i kontrole, a važno je napraviti rasporede pregleda s obzirom na dio sustava koji ima najveći rizik. Baza podataka toga sustava je napravljena i kalibrirana s više od sto slučajeva kanalizacijskih cjevovoda. Pri ocjenjivanju, SCRAPS je pokazao da slično prosuđuje kao i kada bi stručnjak odlučivao o kvaru, premda je ipak bio konzervativniji od stručnjaka.

Giovanelli i Maglionico [60] primjenjuju također SCRAPS kako bi predvidjeli kritične dijelove sustava odvodnje. U bazu podataka SCRAPS-a uneseni su podatci o promjerima cijevi, učestalosti plavljenja, prodorima korijenja, sedimentu, koroziji, starosti cijevi, razini podzemne vode, dubini cijevi, itd. Pokazano je da

uporaba SCRAPS-a uz hidraulično modeliranje može biti vrlo korisno pri vrednovanju podataka o kanalizacijskom sustavu i izradi rasporeda potrebnih pregleda kako bi se očuvala stalna razina služnosti.

Sousa i sur. [61] razvili su ekspertni sustav za podršku pri održavanju sustava odvodnje. Ekspertni sustav služi im kao pomoć i podrška kako bi lakše odredili prioritet čišćenja sustava odvodnje te raspored inspekcijskih pregleda. Razvijeni model primjenjuje sljedeće parametre: vrstu materijala cijevi, starost cijevi, promjer cijevi, nagib, dubinu postavljanja, propuštanje cijevi i karakteristike revizijskog okna (šahta). Ekspertni sustav je također razvijen zato što su informacije kojima javni isporučitelj vodne usluge (JIVU) raspolaže vrlo oskudne, a potrebno je optimizirati aktivnosti održavanja radi uštede novca i vremena. Iako je razvijeni ekspertni sustav vrlo općenit, zbog spomenutih oskudnih informacija, kada bi se raspolagalo s više informacija mogao bi biti od veće koristi, tj. mogao bi modelirati stvarno stanje sustava odvodnje.

Autori Ortolano, Le Coeur i MacGilchrist [62] razvili su ekspertni sustav koji pomaže pri održavanju sustava odvodnje u Parizu, a koji uključuje i dio toga sustava za otkrivanje potreba u vezi s popravcima. Autori zaključuju da treba stvarati bazu podataka o održavanju sustava odvodnje te će trebati što više studija slučaja kako bi se ES validirao i bio što točniji u predviđanju potrebnih aktivnosti održavanja.

Autori Ana i Bauwens [63] napravili su pregled alata za potporu odlučivanju pri upravljanju uporabom i održavanjem sustava odvodnje. Između prilično navedenih alata, spominje se i sustav APOGEE (skr. od franc. *Analyses et Programmation Optimise pour la Gestion, L'Entretien et L'Exploitation du Reseaux d'Assainissement*, eng. *Analysis and Optimal Programming for the Management, Maintenance and Use of a Sewer Network*, hrv. analiza i optimalno programiranje upravljanjem, održavanjem i upotrebom kanalizacijske mreže) razvijen s ciljem optimizacije godišnjeg planiranja i obnove kanalizacijske mreže. Sustav se sastoji od tri osnovne komponente: baze podataka, ekspertnog sustava i modula za planiranje intervencija i popravaka kanalizacijske mreže.

3.5. Genetski algoritmi

Općenito, algoritam je metoda, postupak, pravilo za rješenje nekog problema ili dostizanje nekog cilja, odnosno algoritam je uređeni skup jednoznačnih (nedvosmislenih), izvedivih koraka [96]. Genetske algoritme osmislio je John Holland, a razvio ih je zajedno sa svojim studentima na Sveučilištu Michigan u šezdesetim i sedamdesetim godinama prošlog stoljeća. Hollandov izvorni cilj nije bio oblikovati algoritme za rješavanje specifičnih problema, već proučiti fenomen prilagodbe kao što se događa u prirodi i razviti načine na koje bi mehanizmi prirodne prilagodbe mogli biti implementirani u računalne sustave [97]. Genetski algoritmi (eng. *Genetic algorithms* - GA) prepoznati su kao veoma prikladni za probleme u kojima se javlja višekriterijska optimizacija [98].

Yang i Su [65] u svome su radu pomoću CCTV snimki te neuronskih mreža koje su svrstavale oštećenja na snimkama, genetskih algoritama koji su se rabili za odlučivanje optimalnog načina obnove sustava odvodnje, provodili održavanje sustava odvodnje. Genetski algoritmi su između ostaloga primijenjeni za određivanje najpovoljnije metode obnove i zamjenskog materijala. Na kraju je u geoinformacijskom sustavu (GIS-u) napravljen plan obnove sustava odvodnje te je sve pregledno grafički prikazano [65].

Također i rad [66], razmatra izradu optimizacijskog modela koji je korišten kako bi pronašao odgovarajući način obnove kanalizacijskih cijevi i materijal kojim će se to raditi, i to sve u nekom unaprijed određenom budžetu. Kao rezultat je ostvarena ušteda na obnovi od približno 20 % kada se usporedi sa standardnim stručnim procjenama. Autori Halfway, Dridi i Baker [67] predstavili su slične karakteristike kao autori Yang i Su [66] te je genetski algoritam korišten u svrhu pronalaženja isplativih rješenja za obnovu sustava odvodnje. Autori ovog rada ustvrdili su da je zamjetan nedostatak literature koja obrađuje optimizaciju upravljanja kanalizacijskom mrežom pomoću genetskih algoritama.

Ward i Savić [68] koristili su GA u razvijanju metodologije za optimizaciju obnavljanja sustava odvodnje. Višekriterijski optimizacijski model uključivao je sljedeća tri konfliktna kriterija: maksimizaciju poboljšanja strukturnog stanja sustava, smanjenje građevinskih troškova te minimizaciju rizika kvara sustava odvodnje. Navedeni model testiran je na kanalizacijskom sustavu koji upravlja South West Water, UK. Model je pokazao da teži optimalnim rješenjima koja bi inače bila zanemarena.

Berardi i sur. [69] govore o višekriterijskom pristupu pregledu kanalizacijskih cijevi. Uz pomoć genetskog algoritma rađena je višekriterijska optimizacija rizika od kvara cijevi, troškova pregleda te troškova popravaka.

3.6. Optimizacija kolonijom mrava

Optimizacija kolonijom mrava (eng. *Ant colony optimisation* - ACO) metoda je optimizacije inspirirana ponašanjem kolonija mrava u prirodi. Ta je metoda još uvijek relativno nova, a predložio ju je Marco Dorigo [99, 100]. Algoritam optimizacije kolonijom mrava temelji se na hipotetskom ponašanju mravljeg kolektiva kada su mravi u potrazi za hranom [101-103]. Mravi u svome kretanju luče feromone. Ako nema feromona, mravi se kreću nasumično, međutim ako postoji trag feromona, onda mravi slijede taj put [104]. U prirodi se mravi služe najkraćim putem da dođu do svoga gnijezda te je samim time na tom putu veća koncentracija feromona. Budući da veća koncentracija feromona znači da je više mrava prošlo tim putem, to mravi koriste i u potrazi za hranom, zaobilazanju prepreka, u svakodnevnom životu [101-103]. Količina otpuštenih feromona proporcionalna je kvaliteti rješenja [105]. Ključ uspjeha ACO algoritma je stvaranje novih rješenja [106].

Autori Lukas, Borrmann i Rank [71] koriste ACO pri optimizaciji planiranja pregleda infrastrukturnih građevina, poput mostova i

tunela. Budući da je i sustav odvodnje infrastrukturna građevina, sve bi se isto moglo primijeniti tijekom održavanja toga sustava.

4. Zaključak

U radu se donosi prikaz ekspertnih metoda koje se primjenjuje tijekom optimizacije održavanja sustava odvodnje. Odabir ekspertnih metoda napravljen je na osnovi istraživanja autora o nekim najčešće korištenim ekspertnim metodama, a također i prema dostupnoj literaturi u trenutku pisanja rada.

Održavanje sustava odvodnje je značajno, ali može biti financijski neučinkovito, pogotovo zbog otežane mogućnosti pregleda. Postoji različita oprema za snimanje i pregled kanalizacijskih sustava, ali može biti financijski neučinkovito zbog nemogućnosti pregleda cijele kanalizacijske mreže. Usmjerava se pažnja na određene dijelove sustava za koje se smatra da imaju povećanu

opasnost od kvara ili su stariji od ostatka mreže, u čemu važnu ulogu imaju djelatnici koji se bave održavanjem.

Pregledom dostupnih radova uočeno je da se većina bavi optimizacijom održavanja sustava odvodnje pomoću Markovljevih lanaca, zatim dolaze radovi s umjetnim neuronskim mrežama i ekspertnim sustavima. Također, mogu se koristiti i genetski algoritmi, dok je broj znanstvenih radova sa stabilima odlučivanja i algoritmom kolonije mrava zasad ograničen.

Ekspertne metode primjenjuju se pri optimizaciji održavanja sustava odvodnje, i uočeno je da njihova upotreba ima velikih prednosti. Međutim vidljiva je i dalje slaba primjena, budući da je optimizacija u svakom području potrebna i neophodna, a pogotovo kod održavanja sustava odvodnje kao jednog od značajnijih dijelova infrastrukture svakog naselja i čije je pravilno funkcioniranje važno zbog održavanja adekvatnih sanitarnih uvjeta.

LITERATURA

- [1] Struna, hrvatsko strukovno nazivlje, <http://struna.ihjj.hr/search-do/?q=kanalizacija&naziv=1&polje=0#container>, 28.03.2019
- [2] Kujundžić, B.: Kanalizacioni sistem - definicija, karakteristike, delovi i zadaci, u: Savremena eksploatacija i održavanje objekata i opreme vodovoda i kanalizacije, Udruženje za tehnologiju vode i sanitarno inženjerstvo, Beograd, pp. 345-354, 2010.
- [3] Margeta, J.: Kanalizacija naselja, Građevinski fakultet Sveučilišta u Splitu, Građevinski fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku, Institut građevinarstva Hrvatske-Zagreb, Split, Osijek, 1998.
- [4] Zhang, J., Xiang-Sheng, C., Xue-Zheng, M.: Sustainable urban sewerage system and its application in China, *Resources, Conservation and Recycling*, 51 (2007) 2, pp. 284-293, <https://doi.org/10.1016/j.resconrec.2006.10.001>
- [5] Šperac, M., Moser, V., Stvorić, T.: Održavanje sustava odvodnje uz primjenu GIS-a, *Elektronički časopis Građevinskog fakulteta Osijek - e-GFOS*, 5 (2012), pp. 86-94, doi: <http://dx.doi.org/10.13167/2012.5.8>
- [6] Šperac, M., Hrskanović, I., Šreng, Ž.: Održavanje gravitacijskih kanalizacijskih sustava, 26. Međunarodni znanstveno-stručni skup "Organizacija i tehnologija održavanja - OTO 2017", Zbornik radova, Osijek, pp. 125-131, 2017.
- [7] Obradović, D.: The impact of tree root systems on wastewater pipes, Zbornik radova, Zajednički temelji 2017, Zagreb, pp. 65-71, 2017., <https://doi.org/10.5592/CO/ZT.2017.03>
- [8] Obradović, D.: A short review: Techniques for trenchless sewer rehabilitation, *Conference proceedings, Young scientist 2018*, Slovačka, pp. 1-8, 2018.
- [9] Vugrinec, D.: Priručnik za upravljanje poslovnim zgradama, 2G2e-Udruga za gospodarenje građevinama, energijsku efikasnost, promicanje znanja i vještina, Zagreb, 2012.
- [10] Cerić, A., Katavić, M.: Upravljanje održavanjem zgrada, *GRAĐEVINAR*, 53 (2000) 2, pp. 83-89, <https://hrcak.srce.hr/12216>
- [11] Obradović, D., Marenjak, S.: Uloga održavanja u životnom ciklusu građevine, 26. Međunarodni znanstveno-stručni skup "Organizacija i tehnologija održavanja - OTO 2017", Zbornik radova, Osijek, pp. 61-67, 2017.
- [12] Frković, D., Fruk, T., Buzov, D., Lovrović, M., Škrinjar, D., Preprotić, B., Brandt, K.: Održavanje i gospodarenje imovinom, Hrvatsko društvo održavatelja, Zagreb, 2016.
- [13] Krstić, H.: Model procjene troškova održavanja i uporabe građevina na primjeru građevina Sveučilišta Josipa Jurja Strossmayera u Osijeku, doktorski rad, Sveučilište Josipa Jurja Strossmayera u Osijeku, Građevinski fakultet Osijek, 2011.
- [14] Fenner, A.R.: Approaches to sewer maintenance: a review, *Urban Water*, 2 (2000) 4, pp. 343-356, [https://doi.org/10.1016/S1462-0758\(00\)00065-0](https://doi.org/10.1016/S1462-0758(00)00065-0)
- [15] Hrskanović, I.: Održavanje sustava odvodnje naselja, diplomski rad, Sveučilište J. J. Strossmayera u Osijeku, Građevinski fakultet Osijek, 2016.
- [16] Margeta, J.: Kanalizacija, Građevinski institut, Fakultet građevinskih znanosti Sveučilišta u Splitu, Split, 1990.
- [17] Milojeveć, M.: Snabdevanje vodom i kanisanje naselja, Naučna knjiga, Beograd, 1987.
- [18] Obradović, D.: Prevencija kvarova sprječavanjem rasta i uklanjanjem korijenja drveća u kanalizacijskom cjevima, *VODOPRIVREDA*, 50 (2018) 291-293, pp. 165-173., http://www.vodoprivreda.net/wp-content/uploads/2019/01/16-Dino-Obradovic%C4%87_R.pdf
- [19] Radonić, M.: Vodovod i kanalizacija u zgradama, IRO Građevinska knjiga, Beograd, 1983.
- [20] Reed, A.R.: Sustainable sewerage, Guidelines for community schemes, Water, Engineering and Development Centre, London, 1995.
- [21] Chughtai, F., Zayed, T.: Infrastructure Condition Prediction Models for Sustainable Sewer Pipelines, *Journal of Performance of Constructed Facilities*, 22 (2008) 5, pp. 333-341, [https://doi.org/10.1061/\(ASCE\)0887-3828\(2008\)22:5\(333\)](https://doi.org/10.1061/(ASCE)0887-3828(2008)22:5(333))
- [22] Milojković, I., Despotović, J., Popović, M.: Sewer System Inspection and Maintenance Model for Groundwater Protection, *Water Research and Management*, 6 (2016) 3, pp. 29-34.
- [23] Milojković, I., Despotović, J., Karanović, I.: Model for maintenance of sewerage system based on inspection, *IWA 7th Eastern European Young Water Professionals Conference*, 17.-19. rujna 2015., Beograd, Srbija, pp. 538-543., 2015.

- [24] Torres, J.D., Rodriguez, J.P., Palacio, J.D.: An optimization model for prioritizing sewerage maintenance scheduling, 11 th International Conference on Hydroinformatics, HIC 2014, New York City, USA, 2014, https://academicworks.cuny.edu/cc_conf_hic/331
- [25] Čupić, M., Rao Tummala, M.V., Suknović, M.: Odlučivanje: formalni pristup, četvrto dopunjeno i prerađeno izdanje, Fakultet organizacionih nauka, Beograd, 2001.
- [26] Čupić, E.M.: Uvod u teoriju odlučivanja, Naučna knjiga, Beograd, 1987.
- [27] Nikolić, I., Borović, S.: Višekriterijumska optimizacija, metode, primena u logistici, softver, Centar vojnih škola Vojske Jugoslavije, Beograd, 1996.
- [28] Magdić, D.: Uvod u matematičko modeliranje, Prehrambeno-tehnološki fakultet Osijek, 2011.
- [29] Venkrbec, V., Galić, M., Klanšek, U.: Construction process optimisation – review of methods, tools and applications, GRAĐEVINAR, 70 (2018) 7, pp. 593-606, doi: <https://doi.org/10.14256/JCE.1719.2016>
- [30] Obradović, D.: Review of nature-inspired optimization algorithms applied in civil engineering, Electronic Journal of the Faculty of Civil Engineering Osijek - e-GFOS, 9 (2018) 17, pp. 74-88, <https://doi.org/10.13167/2018.17.8>
- [31] Vujanović, D.B., Spasić, T.D.: Metodi optimizacije, treće, prerađeno i dopunjeno izdanje, Univerzitet u Novom Sadu, Fakultet tehničkih nauka, Novi Sad, 2009.
- [32] Mišljenović, D., Maršić, I.: Umjetna inteligencija, Školska knjiga, Zagreb, 1991.
- [33] Panian, Ž.: Poslovna informatika za ekonomiste, MASMEDIA d.o.o., Zagreb, 2005.
- [34] Hayes, B.: First Links in the Markov Chain, American Scientist, <https://www.americanscientist.org/article/first-links-in-the-markov-chain>, 13.12.2018.
- [35] Ana, V.E., Bauwens, W.: Modeling the structural deterioration of urban drainage pipes: the state-of-the-art in statistical methods, Urban Water Journal, 7 (2010) 1, pp. 47-59, <https://doi.org/10.1080/15730620903447597>
- [36] Wirahadikusumah, R., Abraham, M.A., Castello, J.: Markov decision process for sewer rehabilitation, Engineering, Construction and Architectural Management, 6 (1999) 4, pp. 358-370, <https://doi.org/10.1108/eb021124>
- [37] Marzouk, M., Omar, M.: Multiobjective optimisation algorithm for sewer network rehabilitation, Structure and Infrastructure Engineering, 9 (2013) 11, pp. 1094-1102, <https://doi.org/10.1080/15732479.2012.666254>
- [38] Micevski, T., Kuczera, G., Coombes, P.: Markov Model for Storm Water Pipe Deterioration, Journal of Infrastructure Systems, 8 (2002) 2, pp. 49-56, [https://doi.org/10.1061/\(ASCE\)1076-0342\(2002\)8:2\(49\)](https://doi.org/10.1061/(ASCE)1076-0342(2002)8:2(49))
- [39] Baik, S.H., Abraham, M.D., Gipson, J.D.: Impacts of deterioration based life cycle cost analysis (LCCA) in the assessment of values of wastewater infrastructure assets, Pipeline Division Specialty Congress 2004, 2004., San Diego, California, USA, pp. 1-10.
- [40] Chung, S.H., Hong, T.H., Han, S.W., Son, J.H., Lee, S.Y.: Life Cycle Cost Analysis based Optimal Maintenance and Rehabilitation for Underground Infrastructure Management, Journal of Civil Engineering, 10 (2006) 4, pp. 243-253, <https://doi.org/10.1007/BF02830778>
- [41] Baik, H.S., Jeong, D.S.H., Abraham, M.D.: Estimating Transition Probabilities in Markov Chain-Based Deterioration Models for Management of Wastewater Systems, Journal of Water Resources Planning nad Management, 132 (2006) 1, pp. 15-24, [https://doi.org/10.1061/\(ASCE\)0733-9496\(2006\)132:1\(15\)](https://doi.org/10.1061/(ASCE)0733-9496(2006)132:1(15))
- [42] Lubini, T.A., Fuamba, M.: Modeling of the deterioration timeline of sewer systems, Canadian Journal of Civil Engineering, 38 (2011) 12, pp. 1381-1390, <https://doi.org/10.1139/I11-103>
- [43] Wirahadikusumah, R., Abraham, D., Iseley, T.: Challenging Issues in Modelling Deterioration of Combined Sewers, Journal of Infrastructure Systems, 7 (2001) 2, pp. 77-84, [https://doi.org/10.1061/\(ASCE\)1076-0342\(2001\)7:2\(77\)](https://doi.org/10.1061/(ASCE)1076-0342(2001)7:2(77))
- [44] Jin, Y., Mukherjee, A.: Modeling Blockage Failures in Sewer Systems to Support Maintenance Decision Making, Journal of Performance of Constructed Facilities, 24 (2010) 6, pp. 622-633, [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0000126](https://doi.org/10.1061/(ASCE)CF.1943-5509.0000126)
- [45] McCulloch, S.W., Pitts, W.: A logical calculus of the ideas immanent in nervous activity, The bulletin of mathematical biophysics, 5 (1943) 4, pp. 115-133, <https://doi.org/10.1007/BF02478259>
- [46] Najafi, M., Kulandaivel, G.: Pipeline Condition Prediction Using Neural Networks Models, Pipeline Division Specialty Conference 2005, Houston, Texas, United States, 21.-24. kolovoza 2005, [https://doi.org/10.1061/40800\(180\)61](https://doi.org/10.1061/40800(180)61)
- [47] Jiang, G., Keller, J., Bond, L.P., Yuan, Z.: Predicting concrete corrosion of sewers using artificial neural network, Water Research, 92 (2016) 1, pp. 52-60, <https://doi.org/10.1016/j.watres.2016.01.029>
- [48] Moselhi, O., Shehab-Eldeen, T.: Automated detection of surface defects in water and sewer pipes, Automation in Construction, 8 (1999) 5, pp. 581-588, [https://doi.org/10.1016/S0926-5805\(99\)00007-2](https://doi.org/10.1016/S0926-5805(99)00007-2)
- [49] Sinha, K.S., Fieguth, W.P.: Neuro-fuzzynetwork for the classification of buried pipe defects, Automation in Construction, 15 (2006) 1, pp. 73-83, <https://doi.org/10.1016/j.autcon.2005.02.005>
- [50] Tran, D.H., Perera, C.J.B., Ng, M.W.A.: Markov and Neural Network Models for Prediction of Structural Deterioration of Storm-Water Pipe Assets, Journal of Infrastructure Systems, ASCE, 16 (2010) pp. 167-171, [https://doi.org/10.1061/\(ASCE\)IS.1943-555X.0000025](https://doi.org/10.1061/(ASCE)IS.1943-555X.0000025)
- [51] Tran, H.D., Ng, M.W.A., Perera, C.J.B.: Neural networks deterioration models for serviceability condition of buried stormwater pipes, Engineering Application of Artificial Intelligence, 20 (2007) 8, pp. 1144-1151, <https://doi.org/10.1016/j.engappai.2007.02.005>
- [52] Ebtehaj, I., Bonakdari, H.: Evaluation of Sediment Transport in Sewer using Artificial Neural Network, Engineering Applications of Computational Fluid Mechanics, 7 (2013) 3, pp. 392-392., <https://doi.org/10.1080/19942060.2013.11015479>
- [53] Belson, A.W.: Matching and Prediction on the Principle of Biological Classification, Journal of the Royal Statistical Society, Series C (Applied Statistics), 8 (1959) 2, pp. 65-75, <https://www.jstor.org/stable/2985543>
- [54] Harvey, R.R., McBean, A.E.: Comparing the utility of decision trees and support vector machines when planning inspections of linear sewer infrastructure, Journal of Hydroinformatics, 16 (2014) 6, pp. 1265-1279, <https://doi.org/10.2166/hydro.2014.007>
- [55] Bailey, J., Harris, E., Keedwell, E., Djordjevic, S., Kapelan, Z.: Developing Decision Tree Models to Create a Predictive Blockage Likelihood Model for Real-World Wastewater Networks, Procedia Engineering, 154 (2016), pp. 1209-1216, <https://doi.org/10.1016/j.proeng.2016.07.433>

- [56] Buchanan, B., Sutherland, G., Feigenbaum, E. A.: Heuristic DENDRAL: A program for generating explanatory hypotheses in organic chemistry, Chapter 12, Vol. 4 of Machine Intelligence, Meltzer, B; Michie, D. (eds.), Edinburgh University Press, 1969., pp. 209-254.
- [57] Tagherout, B.W., Bennis, S., Bengassem, J.: A Fuzzy Expert Systems for Prioritizing Rehabilitation of Sewer Networks, Computer-Aided Civil and Infrastructure Engineering, 26 (2011) 2, pp. 146-152, <https://doi.org/10.1111/j.1467-8667.2010.00673.x>
- [58] Hahn, M., Palmer, N.R., Merrill, M. S.: Prioritizing Sewer Line Inspection with an Expert System, 29th Annual Water Resources Planning and Management Conference, June 6-9, 1999., Tempe, Arizona, USA, pp. 1-10.
- [59] Hahn, A.M., Palmer, R.N., Merrill, M.S., Lukas, B.A.: Expert System for Prioritizing the Inspection of Sewers: Knowledge Base Formulation and Evaluation, Journal of Water Resources Planning and Management, 128 (2002) 2, pp. 121-129, [https://doi.org/10.1061/\(ASCE\)0733-9496\(2002\)128:2\(121\)](https://doi.org/10.1061/(ASCE)0733-9496(2002)128:2(121))
- [60] Giovanelli, M., Maglionico, M.: Identification of the optimal level of service sewer networks by means of expert procedure, 11th International conference on Urban Drainage, Edinburgh, Scotland, UK, 2008., pp. 1-10.
- [61] Sousa, V., Silva, M., Veigas, T., Saldanha Matos, J., Martins, J., Teixeira, A.: Technical Management of Sewer Networks – A Simplified Decision Tool, LESAM 2007 – 2nd Leading Edge Conference on Strategic Asset Management, Lisbon, Portugal, 17.-19. listopada 2007.
- [62] Ortolano, L., Le Coeur, G., MacGilchrist, R.: Expert System for Sewer Network Maintenance: Validation Issues, Journal of Computing in Civil Engineering, 4 (1990) 1, pp. 37-54, [https://doi.org/10.1061/\(ASCE\)0887-3801\(1990\)4:1\(37\)](https://doi.org/10.1061/(ASCE)0887-3801(1990)4:1(37))
- [63] Ana, E., Bauwens, W.: Sewer Network Asset Management Decision-Support Tools: A Review, International Symposium on New Directions in Urban Water Management, 12.-14. rujna 2007., UNESCO Paris, pp. 1-8.
- [64] Holland, J.H.: Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence, Michigan Press, 1975.
- [65] Yang, M.D., Su, T.C.: Automation model of sewerage rehabilitation planning, Water Science & Technology, 54 (2006) 11-12, pp. 225-232, <https://doi.org/10.2166/wst.2006.805>
- [66] Yang, M.D., Su, T.C.: An optimization model of sewage rehabilitation, Journal of the Chinese Institute of Engineers, 30 (2007) 4, pp. 651-659, <https://doi.org/10.1080/02533839.2007.9671292>
- [67] Halfawy, R.M., Dridi, L., Baker, S.: Integrated Decision Support System for Optimal Renewal Planning of Sewer Networks, Journal of Computing in Civil Engineering, 22 (2008) 6, pp. 360-372, [https://doi.org/10.1061/\(ASCE\)0887-3801\(2008\)22:6\(360\)](https://doi.org/10.1061/(ASCE)0887-3801(2008)22:6(360))
- [68] Ward, B., Savić, A.D.: A multi-objective optimisation model for sewer rehabilitation considering critical risk of failure, Water Science & Technology, 66 (2012) 11, pp. 2410-2417., doi: <https://doi.org/10.2166/wst.2012.393>
- [69] Berardi, L., Giustolisi, O., Savic, A.D., Kapelan, Z.: An effective multi-objective approach to prioritisation of sewer pipe inspection, Water Science & Technology, 60 (2009) 4, pp. 841-850, <https://doi.org/10.2166/wst.2009.432>
- [70] Colorni, A., Dorigo, M., Maniezzo, V.: Distributed Optimization by Ant Colonies, Proceedings of the first European conference on artificial life, Paris, France, 1991, pp. 134-142.
- [71] Lukas, K., Borrmann, A., Rank, E.: Using Ant Colony Optimization for Infrastructure Maintenance Scheduling, eWork and eBusiness in Architecture, Engineering and Construction, (ed.) Menzel, K.; Scherer, R., CRC Press, Boca Raton, 2010.
- [72] Stanišić, S.: Markovljevi lanci u kontinuiranom vremenu, diplomski rad, Sveučilište J. J. Strossmayera u Osijeku, Odjel za matematiku, Osijek, 2012.
- [73] Uvod u teoriju telekomunikacionog saobraćaja, Markovljevi lanci i teorija redova čekanja, http://www.ucg.ac.me/skladiste/blog_6470/objava_13947/fajlovi/10%20Telekomunikacioni%20saobraćaj.pdf, 31.07.2018.
- [74] Matić, S.: Utjecaj postupaka sprežanja na točnost analize brodograđevnog proizvodnog procesa, završni rad, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zagreb, 2016.
- [75] Aleksander, I., Morton, H.: An introduction to neural computing, Vol. 240, Chapman and Hall, London, 1990.
- [76] Sušanj, I.: Razvoj hidrološkog modela otjecanja s malih slivova temeljen na umjetnoj neuronskoj mreži, doktorski rad, Sveučilište u Rijeci, Građevinski fakultet, Rijeka, 2016.
- [77] Alavala, R.C.: Fuzzy Logic and Neural Networks, Basic Concepts & Applications, New Age International Publishers, New Delhi, 2000.
- [78] Vouk, D., Malus, D., Carević, D.: Neural networks and their application in water management, GRAĐEVINAR, 63 (2011) 6, pp. 547-554., <https://hrcak.srce.hr/70618>
- [79] Obradović, D.: A Short Review: Some Applications of Artificial Intelligence (Expert Systems and Neural Networks) in Hydrotechnics, 10th European Young Water Professionals Conference IWA YWP, Zagreb, 2018., pp. 95-96.
- [80] El-Din, A.G., Smith, W.D., El-Din, M.G.: Application of artificial neural networks in wastewater treatment, Journal of Environmental and Engineering Science, 3 (2004) S1, pp. S81-S95, <https://doi.org/10.1139/s03-067>
- [81] Vouk, D.: Ekspertni sustav podrške pri odabiru optimalnog sustava odvodnje u ruralnim naseljima, disertacija, Sveučilište u Zagrebu, Građevinski fakultet, 2009.
- [82] Cvitanović, M.: Prezentacija znanja stablom odlučivanja, diplomski rad, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Zagreb, 2012.
- [83] Vitorino, D., Coelho, S.T., Santos, P., Sheets, S., Jurkovic, B., Amado, C.: A Random Forest Algorithm Applied to Condition-based Wastewater Deterioration Modeling and Forecasting, Procedia Engineering, 89 (2014), pp. 401-410, <https://doi.org/10.1016/j.proeng.2014.11.205>
- [84] Zekić-Sušac, M.: 4. Stabla odlučivanja, Sveučilište J. J. Strossmayera u Osijeku, Ekonomski fakultet u Osijeku, 2017., http://www.efos.unios.hr/sustavi-poslovne-inteligencije/wp-content/uploads/sites/192/2017/10/P4_Stabla-odlucivanja-2017.pdf, 16.11.2018.
- [85] Kvesić, Lj.: Primjena stabla odlučivanja u kreditnom skoringu, Ekonomski vjesnik, XXVI (2013) 2., pp. 382-390.
- [86] Puppe, F.: Systematic Introduction to Expert Systems, Knowledge Representations and Problem Solving Methods, Springer-Verlag, Berlin, Heidelberg, 1993.
- [87] Terano, T., Asai, K., Sugeno, M.: Fuzzy systems theory and its applications, Academic Press, Inc., London, 1991.
- [88] Djordjevic, B.: Cybernetics in water resources management, Water Resources Publications, Colorado, 1993.

- [89] Đorđević, B., Dašić, T.: Ekspertni sistemi za planiranje i operativno sprovođenje odbrane od poplava, *Vodoprivreda*, 47 (2015) 276-278, pp. 187-202.
- [90] Kurashige, T., Tanaka, N.: Expert system for inner basin drainage, *Stochastic and Statistical Methods in Hydrology and Environmental Engineering*, In: Hipel K.W., Fang L. (eds.) *Stochastic and Statistical Methods in Hydrology and Environmental Engineering*, Water Science and Technology Library, vol 10/2, Springer, Dordrecht, pp. 309-320, 1994., https://doi.org/10.1007/978-94-017-3081-5_23
- [91] Witten, H. I., Frank, E.: *Data Mining, Practical Machine Learning Tools and Techniques*, Second edition, Morgan Kaufmann, 2005.
- [92] Kim, J. B., Bandy, T. J., Gidwani, K. K., Shelton, P. S.: *Artificial Intelligence for U.S. Army Wastewater Treatment Plant Operation and Maintenance*, AD-A200 434, US Army Corps of Engineers, 1988.
- [93] Pomykalski, J.J. i dr.: *Expert Systems*, Wiley Encyclopedia for Electrical and Electronics Engineering, 1999.
- [94] Šperac, M.: *Upotrebljivost neuralnih mreža za određivanje otjecanja u sustavu urbane odvodnje*, disertacija, Sveučilište u Zagrebu, Građevinski fakultet, 2004.
- [95] Jackson, P.: *Introduction to Expert Systems*, Addison Wesley Longman limited, England, 1999.
- [96] Algoritmi, <http://www.sfsb.unios.hr/~mcicak/A1.pdf>, 29.07.2018.
- [97] Mitchell, M.: *An Introduction to Genetic Algorithms*, A Bradford Book The MIT Press Cambridge, Massachusetts, London, England, 1999.
- [98] Fonseca, M.C., Fleming, J.P.: An Overview of Evolutionary Algorithms in Multiobjective Optimization, *Evolutionary Computation*, 3 (1995) 1, pp. 1-16, <https://doi.org/10.1162/evco.1995.3.1.1>
- [99] Carić, T.: *Optimizacija prometnih procesa (nastavni tekst)*, Fakultet prometnih znanosti, Sveučilište u Zagrebu, 2014.
- [100] Dorigo, M., Di Caro, G.; Gambardella, M.L.: Ant algorithms for discrete optimization, *Artificial Life*, 5 (1999) 2, pp. 137-172, <https://doi.org/10.1162/106454699568728>
- [101] Pessoa, M.C., Ranzan, C., Trierweiler, F.L.; Trierweiler, O.J.: Development of Ant Colony Optimization (ACO) Algorithms Based on Statistical Analysis and Hypothesis Testing for Variable Selection, 48 (8), 9th IFAC Symposium on Advanced Control of Chemical Process ADCHEM 2015, 7-10 June, 2015, Whistler, Canada, pp. 901-905, doi: <https://doi.org/10.1016/j.ifacol.2015.09.084>
- [102] Allegrini, F., Olivieri, A.C.: A new and efficient variable selection algorithm based on ant colony optimization. Applications to near infrared spectroscopy/partial least-squares analysis, *Analytica chimica acta*, 699 (2011) 1, pp. 18-25, <https://doi.org/10.1016/j.aca.2011.04.061>
- [103] Li, B., Wang, L., Song, W.: Ant Colony Optimization for the Traveling Salesman Problem Based on Ants with Memory, *Fourth International Conference on Natural Computation*, 18-20 October 2008, Jinan, China, pp. 496-501, <https://doi.org/10.1109/ICNC.2008.354>
- [104] Cordon, O.; Herrera, F., Stützle, T.: A review on the Ant Colony Optimization Metaheuristic: Basis, Models and New Trends, *Mathware & soft computing*, IX (2002) 2-3, pp. 1-35, doi: <http://hdl.handle.net/2099/3624>
- [105] Salama, M. K.; Freitas, A. A.: Learning Bayesian network classifiers using ant colony optimization, *Swarm Intelligence*, 7 (2013) 2-3, pp. 229-254, <https://doi.org/10.1007/s11721-013-0087-6>
- [106] Ojha, K.V.; Abraham, A.; Snášel, V.: ACO for Continuous Function Optimization: A Performance Analysis, 14th International Conference on Intelligent Systems Design and Applications, Okinawa, Japan, 2014, doi: <https://doi.org/10.1109/ISDA.2014.7066253>